

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Antonio Jambrečić

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentori:

Dr. sc. Joško Deur, dipl. ing.

Student:

Antonio Jambrečić

Zagreb, 2017.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se prof.dr.sc Jošku Deuru na mentorskom vodstvu pri izradi rada.

Posebno se zahvaljujem Dr. sc. Branimir Škugor, mag.ing. na strpljenju, savjetima i pomoći pri izradi ovog rada.

Za kraj bih zahvalio svojoj obitelji i prijateljima koji mi pružaju neprestanu podršku za vrijeme studiranja.

Antonio Jambrečić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **Antonio Jambrečić**

Mat. br.: 0035190933

Naslov rada na
hrvatskom jeziku:

**Upravljanje pogonom utičnog hibridnog električnog autobusa
uzimajući u obzir vožnju kroz zone s niskim emisijama**

Naslov rada na
engleskom jeziku:

**Control of a plug-in hybrid electric bus taking into account operation in
low-emission zones**

Opis zadatka:

Kako bi se smanjile emisije štetnih plinova, u gradskom se okruženju uvode posebne zone (engl. skrać. LEZ, Low Emission Zones), u kojima je dopušteno prometovati samo određenim tipovima vozila s naglaskom na električna vozila. Utična hibridna električna vozila (engl. skrać. PHEV, Plug-in Hybrid Electric Vehicle) trebala bi u tim zonama prometovati u potpuno električnom načinu rada, tj. bez emisija štetnih plinova. U tom smislu, PHEV upravljačka strategija bi na temelju informacija o trenutnoj poziciji vozila i poznatoj prometnoj ruti trebala odrediti optimalan način rada pogona kako bi se minimizirala potrošnja goriva te ostvarila električna vožnja u zonama s niskim emisijama. U radu je za PHEV-tip gradskog autobusa i primjer grada Dubrovnika potrebno:

- opisati značajke gradskog autobusnog prijevoza i definirati potencijalne zone s niskim emisijama;
- postaviti kvazistacionarni matematički i simulacijski model PHEV pogona gradskog autobusa;
- provesti optimiranje upravljačkih varijabli PHEV pogona za snimljene vozne cikluse karakteristične prometne rute i prethodno definirane zone s niskim emisijama;
- analizirati rezultate optimiranja te temeljem dobivenih uvida razviti upravljačku strategiju PHEV pogona;
- provesti simulacijsku provjeru upravljačke strategije, uključujući usporedbu s rezultatima optimiranja.

Zadatak zadan:

30. studenog 2016.

Zadatak zadao:

Rok predaje rada:

1. rok: 24. veljače 2017.

2. rok (izvanredni): 28. lipnja 2017.

3. rok: 22. rujna 2017.

Predviđeni datumi obrane:

1. rok: 27.2. - 03.03. 2017.

2. rok (izvanredni): 30. 06. 2017.

3. rok: 25.9. - 29. 09. 2017.

v.d. predsjednika Povjerenstva:

Joško Deur

Izv. prof. dr. sc. Branko Bauer

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	II
POPIS TABLICA.....	III
POPIS OZNAKA	IV
SAŽETAK.....	VI
SUMMARY	VII
1. UVOD.....	1
2. KONCEPT LEZ ZONA NA PRIMJERU GRADA DUBROVNIKA	2
2.1. Karakteristike dubrovačkog javnog prijevoza	2
2.2. Koncept LEZ zona	4
2.3. Potencijalna primjena LEZ zona u Dubrovniku	5
3. SIMULACIJSKI MODEL PHEV AUTOBUSA	7
3.1. Osnovne karakteristike modeliranog tipa autobusa	7
3.2. Modeliranje pogona PHEV busa.....	8
4. OPTIMIRANJE UPRAVLJAČKIH VARIJABLI PHEV POGONA	16
4.1. Dinamičko programiranje	16
4.2. Matematički opis DP algoritma	17
4.3. Implementacija DP algoritma	18
4.4. Primjena DP u svrhu optimiranja upravljačkih varijabli PHEV pogona	18
5. REZULTATI OPTIMIRANJA.....	21
5.1. Usporedba potrošnje goriva	21
6. RAZVOJ UPRAVLJAČKE STRATEGIJE	24
6.1. Koncept upravljačke strategije s primjenom na LEZ zone	24
6.2. Rezultati realistične upravljačke strategije	25
7. ZAKLJUČAK.....	28
8. PRILOG.....	29
8.1. C kod realistične upravljačke strategije	29
LITERATURA.....	32
PRILOZI.....	33

POPIS SLIKA

Slika 1.	Mreža gradskih linija.....	3
Slika 2.	Snimljena ruta autobusne linije Babin Kuk – Pile.....	4
Slika 3.	Snimljeni i filtrirani profili brzine vozila i nagiba ceste.....	4
Slika 4.	Rasprostranjenost LEZ zona u europskim gradovima.....	5
Slika 5.	Primjer signalizacije ulaska u LEZ zonu, London.....	6
Slika 6.	Potencijalne LEZ zone za grad Dubrovnik.....	6
Slika 7.	Raspored LEZ zona na trasi linije Babin Kuk – Pile.....	7
Slika 8.	Stupnjevi prijenosa automatskog mjenjača Volvo AT2412D I-Shift.....	9
Slika 9.	Paralelna konfiguracija hibridnih vozila.....	9
Slika 10.	Blok dijagram kvazistatičkog modela autobusa.....	10
Slika 11.	Blok dijagram upravljačke strategije.....	11
Slika 12.	Mapa specifične potrošnje goriva [g/kWh].....	13
Slika 13.	Mapa korisnosti električnog stroja	14
Slika 14.	Nadomjesni električni krug baterije.....	15
Slika 15.	Otpor punjenja i pražnjenja za jednu ćeliju litij-ionske baterije.....	16
Slika 16.	Usporedba stanja SoC-a sa i bez uključenih LEZ zona.....	23
Slika 17.	Optimalne radne točke SUI motora za slučaj sa i bez uključenim LEZ zonama...23	
Slika 18.	Optimalne radne točke ES-a za slučaj sa i bez uključenim LEZ zonama.....	24
Slika 19.	Usporedba zahtijevane P_d i isporučene snage $P_{ice}+P_{mg}$	26
Slika 20.	Moment SUI motora.....	27
Slika 21.	Radne točke SUI motora za uključene LEZ zone dobivene DP optimiranjem i realističnom strategijom.....	28
Slika 22.	Radne točke ES-a za uključene LEZ zone dobivene DP optimiranjem i realističnom strategijom.....	28

POPIS TABLICA

Tablica 1.	Osnovni patametri vozila.....	8
Tablica 2.	Popis veličina vezanih uz jednadžbe 3.1 i 3.2.....	10
Tablica 3.	Popis veličina vezanih uz jednadžbe 3.4. do 3.8.....	12
Tablica 4.	Maksimalne vrijednosti za SUI motor.....	13
Tablica 5.	Maksimalne vrijednosti za ES.....	15
Tablica 6.	Parametri baterije.....	15
Tablica 7.	Optimalna potrošnja goriva za vozne cikluse.....	22
Tablica 8.	Usporedba potrošnje goriva za uključene LEZ zone.....	27

POPIS OZNAKA

Oznaka	Jedinica	Opis
l	m	duljina vozila
w	m	širina vozila
h	m	visina vozila
A_f	m ²	prednja površina vozila
r	m	ekvivalentni polumjer gume
m	kg	masa praznog vozila
ω_{kot}	rad/s	kutna brzina kotača
τ_{kot}	Nm	zahtijevani moment na kotaču
μ_{kot}	-	faktor trenja otpora kotrljanja
C_d	-	aerodinamički otpor zraka
ρ_{zr}	kg/m ³	gustoća zraka
g	m/s ²	ubrzanje sile teže
α	°	nagib ceste
P_d	W	zahtijevana snaga
h	-	stupanj prijenosa
i_o	-	prijenosni omjer diferencijala
η_t	-	korisnost transmisije
τ_{mg}	Nm	moment električnog stroja
ω_{mg}	rad/s	kutna brzina električnog stroja
τ_{ice}	Nm	moment SUI motora
ω_{ice}	rad/s	kutna brzina SUI motora
P_{ice}	W	snaga SUI motora
P_{mg}	W	snaga električnog stroja
\bar{m}_f	g/kWh	specifična potrošnja goriva
\dot{m}_f	g/s	maseni protok goriva
$m_{f,uk}$	L	ukupna potrošnja goriva
P_{max}	kW	maksimalna snaga
E	kWh	energija baterija
Q	Ah	kapacitet baterije
m_{bat}	kg	masa baterije
SoC	-	stanje napunjenosti baterije
R_{ch}	Ω	unutarnji otpor pri punjenju baterije
R_{dch}	Ω	unutarnji otpor pri pražnjenju baterije
U_{oc}	V	napon otvorenog kruga baterije
t_f	s	vrijeme trajanja ciklusa

N_t	-	broj intervala uzorkovanja
\mathbf{x}	-	vektor varijabli stanja
\mathbf{u}	-	vektor upravljačkih varijabli

SAŽETAK

U ovome radu prikazan je utjecaj uvođenja LEZ (engl. skrać. LEZ, Low Emission Zones) zona na primjeru utičnog hibridnog električnog (engl. skrać. PHEV, Plug-in Hybrid Electric Vehicle) autobusa u Dubrovniku. LEZ zone predefinirana su područja u kojima je cilj smanjiti emisiju štetnih plinova te buku u urbanim sredinama. PHEV vozila u tim bi zonama trebala prometovati na isključivo električan pogon koji im omogućuje velika baterija. Osim baterije, ovakva vozila posjeduju i motor sa unutarnjim izgaranjem te je stoga potrebna upravljačka strategija koja ovisno o trenutnim uvjetima određuje parametre pogona. Za potrebe simulacije postaviti će se kvazistacionaran model autobusa te je provesti optimiranje upravljačkih varijabli pogona korištenjem algoritma dinamičkog programiranja. (engl. skrać. DP, Dynamic Programming). Dobiveni rezultati poslužit će za validaciju potrošnje goriva u LEZ zonama te za daljnji razvoj realistične upravljačke strategije.

Ključne riječi: utični hibridni električni autobus, Low Emission Zones (LEZ), Dubrovnik, vozni ciklusi, kvazistacionaran model, dinamičko programiranje, stanje napunjenosti baterije, potrošnja goriva.

SUMMARY

The aim of this paper was to review effects of introducing LEZ (Low Emission Zones) for PHEV (Plug-in Hybrid Electric Vehicle) public buses in Dubrovnik. LEZ zones are defined areas with objective to reduce emission of polluting gasses and noise in urban environment. In those zones, PHEV vehicles should drive exclusively in electric mode due to big battery they have. Except battery, these vehicles possess engine so there has to be a control system which decides about vehicle's powertrain. For simulation purposes, quasistatic model of the bus will be developed and its powertrain system will be optimized with dynamic programming (DP) algorithm. Collected results will be used to validate fuel consumption in LEZ zones and also for further development of powertrain control system.

Key words: PHEV (Plug-in Hybrid Electric Vehicle), Low Emission Zones (LEZ), Dubrovnik, quasistatic model, driving cycle, state of charge, dynamic programming, fuel consumption.

1. UVOD

Utična hibridna električna vozila (engl. skrać. PHEV, Plug-in Hybrid Electric Vehicle) za razliku od ostalih hibridnih vozila posjeduju veliku bateriju koja im omogućuje vožnju u potpuno električnom načinu rada. Budući da takva vozila mogu prometovati u dva različita režima rada, potrebna je upravljačka strategija koja određuje tok snage u SUI odnosno električnom motoru. U ovome radu prikazana je implementacija upravljačke strategije PHEV gradskog autobusa s obzirom na posebno definirane zone niskih emisija (engl. skrać. LEZ, Low Emission Zones). U tim zonama PHEV vozila bi trebala prometovati u potpuno električnom režimu rada. Zadatak upravljačke strategije je da na temelju informacija o trenutnoj poziciji vozila i poznatoj prometnoj ruti odredi optimalan način rada pogona koji minimizira potrošnju goriva te osigurava električnu vožnju kroz LEZ zone [1].

Za potrebe simulacije je postavljen kvazistacionaran model autobusa marke Volvo 7900 za kojeg će se simulirati vožnja prema snimljenim voznim ciklusima. Za usporedbu rezultata koristit će se algoritam dinamičkog programiranja (engl. skrać. DP, Dynamic Programming) koji daje globalno optimalno rješenje. Na temelju toga dobit će se optimalni podaci o potrošnji goriva za slučajeve sa i bez uključenih LEZ zona. Dobiveni rezultati poslužit će kao referenca za izradu i validaciju realistične upravljačke strategije.

2. KONCEPT LEZ ZONA NA PRIMJERU GRADA DUBROVNIKA

U ovome poglavlju definirat će se potencijalna primjena LEZ zona na primjeru grada Dubrovnika. Kratko će biti opisane karakteristike javnog prijevoza te će se predstaviti snimljeni podaci za jedan vozni ciklus. Za kraj će se odabrati potencijalne LEZ zone za koje će se vršiti simulacija.


2.1. Karakteristike dubrovačkog javnog prijevoza

Posao javnog gradskog prijevoza u Dubrovniku obavlja firma LIBERTAS-DUBROVNIK d.o.o. koja vrši autobusni prijevoz na ukupno 11 linija kako je prikazano na Slici 1 [2]. U prosincu 2014. godine snimani su podaci za kružnu rutu 6 Babin Kuk – Pile [3]. Riječ je o jednoj od najfrekventnijih autobusnih linija u gradu gdje u sezoni autobusi kreću sa polazišta svakih 10-15 min te u prosjeku svaki vozač preveze 1000 ljudi u smjeni. Na liniji ukupno vozi 6 autobusa koji zbrojeno svaki dan prevale put veći od 1200 km.




Slika 1: Mreža gradskih linija

Prilikom snimanja mjerene su vrijednosti položaja, brzine te nagiba koje će poslužiti kao osnova u daljnjem proračunu. Pri mjerenju je također zabilježen i broj putnika nakon svake stanice što je bitno za izračun ukupne mase vozila. Zbog radova u trenutku snimanja, snimljena ruta je nešto drugačija od uobičajene.




Slika 2: Snimljena ruta autobusne linije Babin Kuk – Pile



Slika 3: Snimljeni i filtrirani profili brzine vozila i nagiba ceste

2.2. Koncept LEZ zona

LEZ zone (često se koristi i izraz „zelene zone“) predefinirana su geografska područja gdje je zakonom propisana dozvoljena emisija štetnih plinova. [4] Zakon se najčešće provodi tako da vozila koja ne zadovoljavaju kriterij moraju platiti penal za ulazak u zonu. S obzirom da je i dalje većina vozila na cestama pogonjena isključivo SUI motorom, LEZ zone uglavnom se primjenjuju na vozila više kategorije kao što su dostavna vozila te autobusi. Danas su zelene zone prisutne u više od 220 gradova diljem Europe.



Slika 4: Rasprostranjenost LEZ zona u europskim gradovima [5]

Osnovna ideja LEZ zona je da se smanjenjem emisije štetnih plinova poboljša kvaliteta zraka u urbanim područjima, no to nije jedina prednost. Uvođenje zelene zone također pozitivno utječe i na smanjenje buke jer električni motor radi mnogo tiše od SUI motora. Nije zanemariva ni činjenica da se eliminacijom vozila koja ne zadovoljavaju kriterije zone oslobađa prostor za ostala vozila pa se tako smanjuje gužva na cestama.



Slika 5: Primjer signalizacije ulaska u LEZ zonu, London


2.3. Potencijalna primjena LEZ zona u Dubrovniku

Dubrovnik sa svojih 40-tak tisuća stanovnika zasigurno ne predstavlja mjesto velike koncentracije zagađenja no tijekom sezone broj ljudi i vozila višestruko naraste pa sa time porastu i ostali negativni faktori a to su zagađenje zraka, buka i gužva. U kontekstu ovog rada analizirat će se isključivo aspekti primjene zelenih zona na javni gradski autobus. Za potrebe simulacija predložene su dvije LEZ zone.



Slika 6: Potencijalne LEZ zone za grad Dubrovnik

Crvena zona obuhvaća uži prostor oko centra. Svrha te zone primarno bi bila da se smanji buka i gužva oko stare gradske jezgre. Plava zona obuhvaća prostor oko luke koji je često najzagađeniji dio grada zbog koncentracije morskih plovila. S obzirom na kružnu rutu kojom se autobus kreće, u tijeku jednog ciklusa on će dvaput proći kroz plavu zonu i jednom kroz crvenu.



Slika 7: Raspored LEZ zona na trasi linije Babin Kuk – Pile

3. SIMULACIJSKI MODEL PHEV AUTOBUSA


U ovome poglavlju postavljen je kvazistacionaran model PHEV autobusa [6]. Modelu će biti pridijeljena početna upravljačka strategija a u idućem poglavlju bit će dodana logika vezana uz LEZ zone. Podaci i karakteristike koje ulaze u proračun temelje se na modelu busa Volvo 7900 [7].

3.1. Osnovne karakteristike modeliranog tipa autobusa

Tablicom 1. prikazani su osnovni parametri vozila vezani uz masu, geometriju i predviđeni broj putnika u autobusu. Upravljanje transmisijom vrši se preko 12 brzinskog automatskog mjenjača Volvo AT2412D I-Shift čiji prijenosni omjeri su prikazani slikom 8 [8].

Varijabla	Oznaka	Vrijednost	Mjerna jedinica
duljina	l	12.0	m
širina	w	2.55	m
visina	h	3.28	m
prednja površina vozila	A_f	8.364	m ²
ekvivalentni polumjer gume	r	0.441	m
broj putnika	n_p	105	-
masa praznog vozila	m	11650	kg


Tablica 1: osnovni parametri vozila



Slika 8: Stupnjevi prijenosa automatskog mjenjača Volvo AT2412D I-Shift

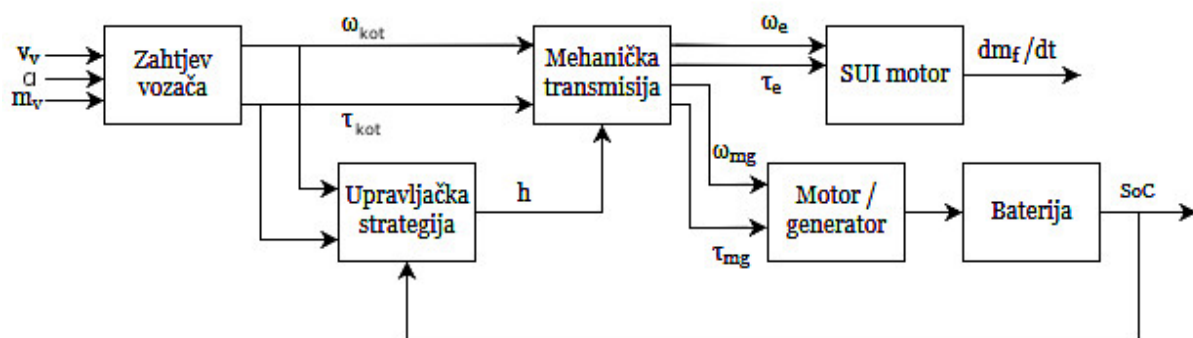
3.2. Modeliranje pogona PHEV busa

Autobus Volvo 7900 izveden je kao hibrid paralelne konfiguracije. To znači da vozilo može biti pogonjeno od strane SUI i električnog motora. Oba motora nezavisna su jedan o drugome te mogu raditi samostalno ili u paru. Prikaz paralelne hibridne konfiguracije vozila dan je na slici 9.



Slika 9: Paralelna konfiguracija hibridnih vozila

Osnova shema kvazistatičkog modela autobusa prikazana je blok dijagramom na slici 10.



Slika 10: Blok dijagram kvazistatičkog modela autobusa

Veličine koje ulaze u blok „Zahtjev vozača“ snimljene su vrijednosti koje predstavljaju ulaz u kvazistatički model. Na temelju tih vrijednosti računa se kutna brzina kotača ω_{kot} te moment koji je potrebno generirati na kotaču T_{kot} . Moment na kotaču mora biti dovoljan da zadovolji sile akceleracije, gravitacije, otpora kotrljanja te silu aerodinamičkog otpora. Izlazne veličine ω_{kot} i τ_{kot} računaju se prema formulama 3.1. i 3.2 te proslijeđuju do bloka upravljačke strategije.

$$\omega_{kot} = \frac{v_v}{r} \quad (3.1)$$


$$\tau_{kot} = r \left(m \left[dv_v / dt + g (\sin \alpha + \mu_{kot} \cos \alpha) \right] + 0.5 \rho_{zr} C_d A_f v_v^2 \right) \quad (3.2)$$

Varijabla	Oznaka	Vrijednost	Mjerna jedinica
faktor trenja otpora kotrljanja	μ_{kot}	0.012	-
aerodinamički otpor zraka	C_d	0.7	-
gustoća zraka	ρ_{zr}	1.225	kg/m ³
ubrzanje sile teže	g	9.81	m/s ²
nagib ceste	α	-	[°]

Tablica 2: Popis veličina vezanih uz jednadžbe 3.1 i 3.2

Upravljačka strategija ima dvije glavne zadaće a to su odrediti tok energije i optimalan stupanj prijenosa h . Logika upravljačke strategije za određivanje toka energije vrlo je jednostavna i svodi se na pravilo: „vozi u potpuno električnom režimu sve dokle zahtijevana snaga P_d ne postane veća od nekog unaprijed definiranog praga P_{prag} , tada uključi SUI motor“. Zahtijevana snaga P_d odnosi se snagu zahtijevanu na kotaču a računa prema formuli:

$$P_d = \omega_{\text{kot}} \cdot \tau_{\text{kot}} \quad (3.3)$$



Slika 11: Blok dijagram upravljačke strategije

Na snagu P_d zatim se dodaje izlaz iz SoC regulatora. SoC regulator proporcionalan je regulator koji grešku odstupanja SoC-a od zadane referentne vrijednosti SoC_R množi sa faktorom 10^5 . Dobivena vrijednost P_{bat} je snaga kojom će se ovisno o predznaku puniti ili prazniti baterija. Vrijednost P_{bat} zbraja se sa zahtijevanom snagom P_d te se dobiva snaga motora P_e koja se uspoređuje sa pragom P_{prag} te ovisno o veličini uključuje ili isključuje SUI motor. Svrha uvođenja praga jest da se izbjegava korištenje SUI motora u području visoke specifične potrošnje goriva te da se forsira električni režim rada.

Druga glavna zadaća upravljačke strategije jest da odredi optimalan stupanj prijenosa h kojim će se ostvariti maksimalna korisnost električnog stroja odnosno minimalna potrošnja goriva. To se određuje tako da se *for* petljom ispita svaki od 12 stupnjeva prijenosa te se za svaki stupanj izračuna korisnost ES odnosno potrošnja goriva. Stupanj prijenosa koji je za zadane uvjete troši najmanje energije je optimalan te kao takav ulazi dalje u proračun.

Ako je režim rada isključivo električan, moment i brzina električnog stroja se računaju prema jednadžbama 3.4 i 3.5

$$\tau_{\text{mg}} = \frac{\tau_{\text{kot}}}{\eta_t i_o h} \quad (3.4)$$

$$\omega_{\text{mg}} = \omega_{\text{kot}} i_o h \quad (3.5)$$

Ako je SUI motor uključen tada se njegovi moment i brzina računaju prema jednadžbama 3.6 i 3.7

$$\tau_{\text{ice}} = \frac{\tau_{\text{kot}}}{\eta_t i_o h} \quad (3.6)$$

$$\omega_{\text{ice}} = \omega_{\text{kot}} i_o h \quad (3.7)$$

U tom slučaju se brzina električnog stroja ω_{mg} izjednačava sa brzinom SUI motora ω_e a moment se računa prema izrazu:


$$\tau_{\text{mg}} = \frac{P_d - P_{\text{ice}}}{\omega_{\text{mg}}} \quad (3.8)$$

Varijabla	Oznaka	Vrijednost	Mjerna jedinica
stupanj prijenosa	h	promijenjiva	-
prijenosni omjer diferencijala	i_o	4.72	-
korisnost transmisije	η_t	0.95	-

Tablica 3: Popis veličina vezanih uz jednadžbe 3.4 do 3.8

Dobivene vrijednosti ω_e i τ_e zatim se proslijeđuju do bloka SUI motor gdje se potrošnja goriva vadi pomoću mape specifične potrošnje goriva $m_f(\omega_{kot}, \tau_{kot})$ prema formuli:

$$\dot{m}_f(\tau_{ice}, \omega_{ice}) = \frac{\tau_{ice} \omega_{ice} \bar{m}_f(\tau_{ice}, \omega_{ice})}{1000 \cdot 3600} \quad (3.9)$$



Slika 12: Mapa specifične potrošnje goriva [g/kWh] [6]

Ukupna potrošnja goriva u litrama dobije se integracijom gdje t predstavlja ukupno trajanje ciklusa u sekundama:


$$m_{f,uk} = \int_0^t \dot{m}_f(\tau_{ice}, \omega_{ice}) dt \quad (3.10)$$

SUI motor modeliran je prema motoru koji se nalazi u modelu autobusa Volvo 7900, a to je Volvo D5K240 EU6 [9]. Prilikom izračunavanja veličina vezanih za SUI motor uzete su u obzir maksimalne vrijednosti snage, brzine i momenta motora.

Varijabla	Oznaka	Vrijednost	Mjerna jedinica
maksimalna snaga	P_{max}	177	kW
maksimalan broj okretaja	ω_{max}	2700	o/min
maksimalni moment	τ_{max}	900	Nm

Tablica 4: Maksimalne vrijednosti za SUI motor

Veličine ω_{mg} i τ_{mg} koje izlaze iz bloka mehaničke transmisije prosljeđuju se do bloka vezanog uz električni stroj. Električni stroj modeliran je prema motoru Volvo I-SAM koji se nalazi u busu Volvo 7900. Nažalost za taj motor nije dostupna mapa korisnosti pa je ona preuzeta od motora sličnih karakteristika a to je Remy HVH 410[10]. Kao i kod SUI motora, na temelju veličina brzine i momenta iz mape korisnosti očitava se korisnost η_{mg} .



Slika 13: Mapa korisnosti električnog stroja sa pripadajućom krivuljom maksimalnog momenta [6]

Ovisno o tome radi li ES u motorskom ili generatorskom režimu izračunava se snaga ES koja potom ulazi u blok baterije.

$$P_{mg,mot} = \frac{\tau_{mg} \omega_{mg}}{\eta_{mg}} \quad (3.11)$$

$$P_{mg,gen} = (\tau_{mg} \omega_{mg}) \eta_{mg} \quad (3.12)$$

Kao i za SUI motor i ovdje se vodilo računa o tome da se pri izračunu ne prekrše maksimalne vrijednosti za motor.

Varijabla	Oznaka	Vrijednost	Mjerna jedinica
maksimalna snaga	P_{\max}	120	kW
maksimalan broj okretaja	ω_{\max}	2700	o/min
maksimalni moment	τ_{\max}	800	Nm


Tablica 5: Maksimalne vrijednosti za ES

Blok baterije snagu P_{bat} koja se dovodi bateriji dovodi se u vezu sa stanjem napunjenosti baterije SoC . Baterija je modelirana prema podacima za litij-ionsku bateriju te sadrži 317 ćelija. Parametri baterije dani su u tablici 6.

Varijabla	Oznaka	Vrijednost	Mjerna jedinica
energija	E	19000	kWh
kapacitet	Q	50.72	Ah
masa	m_{bat}	200	kg

Tablica 6: Parametri baterije


Za opis veze između SoC i P_{bat} koristi se nadomjesni krug baterije prikazan slikom 14.



Slika 14: Nadomjesni električni krug baterije

Iz toga se pomoću osnovnih zakona elektrotehnike izvodi jednačba koja opisuje promjenu SoC -a u vremenu.

$$S\dot{o}C = \frac{\sqrt{U_{oc}^2(SoC) - 4R(SoC,i)P_{bat}} - U_{oc}(SoC)}{2Q_{\max}R(SoC,i)} \quad (3.13)$$



Slika 15: Otpor punjenja i pražnjenja za jednu ćeliju litij-ionske baterije

4. OPTIMIRANJE UPRAVLJAČKIH VARIJABLI PHEV POGONA

U ovome poglavlju dan je prikaz optimiranja upravljačkih varijabli pogona korištenjem dinamičkog programiranja. Dobiveni podaci kasnije će poslužiti kao referenca za izradu i validaciju upravljačke strategije.

4.1. Dinamičko programiranje

Algoritam dinamičkog programiranja predstavlja metodu rješavanja složenog problema na način da se on razdjeli na skup jednostavnijih podproblema čija se rješenja spremaju u memoriju. Sljedeći put kada se pojavi isti podproblem, umjesto ponovnog računanja jednostavno se uzme rješenje koje je prethodno izračunato te se na taj način dobiva ušteda na vremenu.

Ideja ovog algoritma je da se minimizira vremenski diskretna funkcija cilja koja je definirana jednadžbom:

$$J = \sum_{k=0}^{N_t-1} F(x_{k+1}, u_k, k) \quad (4.1)$$

u kojoj N_t predstavlja broj diskretnih vremenskih intervala, $\mathbf{x}k = \mathbf{x}(tk)$ i $\mathbf{u}k = \mathbf{u}(tk)$ su varijable vektora stanja i upravljanja u k -tom vremenskom intervalu $tk = kT$ gdje je T vrijeme uzorkovanja definirano kao $T = tf / N$. Skup vremenski kontinuiranih jednadžbi koje izvorno opisuju proces transformira u skup jednadžba diferencije:

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k, k), \quad k = 0, 1, \dots, N-1 \quad (4.2)$$

Početni i krajnji uvjeti za vektor stanja su :

$$\mathbf{x}_0 = \mathbf{x}(0) \quad (4.3)$$

$$\mathbf{x}_N = \mathbf{x}_f = \mathbf{x}(t_f) \quad (4.4)$$

gdje je vektor upravljanja je ograničen u svojoj domeni na iduće minimalne i maksimalne vrijednosti (tzv. tvrda ograničenja):

$$\mathbf{u}_{\min} \leq \mathbf{u}_k \leq \mathbf{u}_{\max}, \quad k = 0, 1, \dots, N-1 \quad (4.5)$$

U podintegralnoj funkciji $F(x_{k+1}, u_k, k)$ u jednadžbi (4.1.) mogu biti uključene i dodatne penalizacije ako postoje ograničenja na upravljačke varijable i varijable stanja (meka ograničenja).

4.2. Matematički opis DP algoritma

Ako funkciju cilja iz jednadžbe (4.1.) zapišemo na drugačiji način:

$$J_N(x_0) = \min_{u_0, \dots, u_{N-1}} \sum_{k=1}^N F(x_k, u_{k-1}, k) \quad (4.6)$$

te ako primijenimo iz jednadžbe diferencije (4.2.) da \mathbf{x}_1 ovisi samo o \mathbf{x}_0 i \mathbf{u}_0 dobivamo :

$$J_N(x_0) = \min_{u_0} \left[F(x_1, u_0, 0) + \min_{u_0, \dots, u_{N-1}} \sum_{k=2}^N F(x_k, u_{k-1}, k) \right] \quad (4.7)$$

$$J_N(x_0) = \min_{u_0} \left[F(f(x_1, u_0, 0), u_0, 1) + J_{N-1}(f(x_0, u_0, 0)) \right] \quad (4.8)$$

Iz toga se da zaključiti kako se k -ti problem odnosi na $(k-1)$ -ti problem te se izvodi slijedeća rekurzivna jednadžba za $k = 2, 3, \dots, N$:

$$J_k(x_{N-k}) = \min_{u_{N-k}} \left[F(f(x_{N-k}, u_{N-k}, N-K), u_{N-k}, N-k+1) + J_{k-1}(f(x_{N-k}, u_{N-k}, N-K)) \right] \quad (4.9)$$

gdje $k = 1$ predstavlja prvi unazadni (rekurzivni) proces u vremenu koji se rješava. To znači da je $\mathbf{x}_n = \mathbf{x}_f$ te se problem svodi na:

$$J_1(x_{N-1}) = \min_{u_{N-1}} F(x_f, u_{N-1}, N) \quad (4.10)$$

$$J_1(x_{N-1}) = \min_{u_{N-1}} F(f(x_{N-1}, u_{N-1}, N-1), u_{N-1}, N) \quad (4.11)$$

Prema gore navedenim jednadžbama da se zaključiti da se sveukupno rješenje problema sastoji od rješavanja i memorizacije podproblema za svaki vremenski trenutak počevši od trenutka $J_1(\mathbf{x}_{N-1})$ uz odgovarajuće vrijednosti upravljačkog vektora \mathbf{u}_{N-1} . Pretraživanjem prostora za \mathbf{u} ($\mathbf{u}_{\min} \leq \mathbf{u}_k \leq \mathbf{u}_{\max}$) dobivamo optimalni upravljački vektor \mathbf{u}_{N-1} . Idući korak je računanje rekurzivne jednadžbe (4.11.) s ciljem dobivanja $[J_1(\mathbf{x}_{N-1}), \mathbf{u}_{N-1}]$, $[J_2(\mathbf{x}_{N-2}), \mathbf{u}_{N-2}]$, ..., $[J_N(\mathbf{x}_0), \mathbf{u}_0]$ (tzv. optimiranje unazad u vremenu). Budući da je \mathbf{x}_0 unaprijed definiran, u posljednjem koraku potrebno je tražiti optimalnu vrijednost u_0 za $[J_N(\mathbf{x}_0), \mathbf{u}_0]$ samo za prethodno poznat \mathbf{x}_0 .

Nakon optimiranja slijedi faza rekonstrukcije optimalnog rješenja (unaprijed u vremenu) gdje se optimalno rješenje rekonstruira iz prethodno spremljenih optimalnih rješenja iz ranije faze optimiranja. Korištenjem x_0 i u_0 te $\mathbf{x}_1 = \mathbf{f}(\mathbf{x}_0, \mathbf{u}_0, 0)$ dobiva se slijedeći vektor stanja \mathbf{x}_1 jer imamo zapamćene vrijednosti $\{J_{N-1}(\mathbf{x}_1), \mathbf{u}_1\}$ koje odgovaraju točno definiranoj vrijednosti $\mathbf{x}_1 =$

$f(\mathbf{x}_0, \mathbf{u}_0, 0)$. Taj postupak se ponavlja za svaki idući vremenski trenutak te dobivamo optimalni upravljački vektor $\{\mathbf{u}_0, \mathbf{u}_1, \dots, \mathbf{u}_{N-1}\}$. [11]

4.3. Implementacija DP algoritma

Za ispravnu implementaciju DP algoritma potrebno je:

1. Definirati problem - postaviti funkciju cilja, početno i krajnje stanje \mathbf{x}_0 i \mathbf{x}_f (4.3) te formulirati proces u diskretnom vremenu (4.2)
2. Odrediti broj uzoraka (rezoluciju) vektora stanja (N_{x_1}, \dots, N_{x_n}), vektora upravljanja (N_{u_1}, \dots, N_{u_n}) te vremena (N_t)
3. Postaviti donje i gornje granice svih bitnih varijabli (vremena t , stanja \mathbf{x}_{\min} i \mathbf{x}_{\max} , upravljačkih varijabli \mathbf{u}_{\min} i \mathbf{u}_{\max})
4. Alocirati matrice za spremanje rješenja

\mathbf{J}_{opt} – za sustav prvog reda (jedna varijabla stanja) matrica je dvodimenzionalna te sadrži minimalne vrijednosti funkcije cilja za zadana stanja i vrijeme. Dimenzija matrice je $N_x \times N_t$ gdje redci predstavljaju vrijednosti varijable stanja a stupci diskretne vremenske trenutke. Porastom broja varijabli stanja raste i dimenzija matrice pa tako za dvije varijable stanja matrica postaje trodimenzionalna.

\mathbf{U}_{opt} – dvodimenzionalna matrica u koju se pohranjuju optimalne vrijednosti upravljačke varijable za sva diskretna stanja i vremena. Dimenzija matrice je $N_x \times N_t$ te je broj ovih matrica određen brojem upravljačkih varijabli.

Kako bi se povećala točnost, u fazi optimiranja se koristi linearna interpolacija pri računanju vrijednosti ciljne funkcije \mathbf{J}_{k-1} te podintegralne funkcije F u rekurzivnoj jednadžbi (4.10) za slučaj kada nova vrijednost u vektoru stanja $\mathbf{x}_{N-k+1} = f(\mathbf{x}_{N-k}, \mathbf{u}_{N-k}, N-k)$ poprimi vrijednost između vrijednosti definiranih rezolucijom.

4.4. Primjena DP u svrhu optimiranja upravljačkih varijabli PHEV pogona

Slijedeći gore navedene korake algoritam dinamičkog programiranja primijenjen je sa ciljem minimizacije potrošnje goriva. Kao varijabla stanja uzeta je vrijednost stanja napunjenosti baterije ($\mathbf{x}_k = SoC$) koja može poprimiti vrijednosti od $SoC_{\min} = 0$ do $SoC_{\max} = 1$ a odabrana je rezolucija od 100 točaka. Zadan je uvjet da su vrijednosti početnog i krajnjeg SoC -a jednake

($SoC_{init} = SoC_{target}$). Upravljačke varijable su moment SUI motora τ_e , i stupanj prijenosa h . Moment τ_e može poprimiti vrijednosti u rasponu od $\tau_{e,min} = 0$ do $\tau_{e,max} = 900$ [Nm] te je također uzeta rezolucija od 100 točaka. Obje vrijednosti rezolucije SoC -a i τ_e odabrane su u skladu s preporukama iz literature [6]. Vrijednosti prijenosnog omjera h definirane su transmisijским sustavom autobusa te poprimaju jednu od diskretnih vrijednosti [14.94, 11.73, 9.04, 7.09, 5.44, 4.35, 3.44, 2.7, 2.08, 1.63, 1.27, 1]. Vrijeme je diskretizirano sa $\Delta T = 1$ s.

Iz poznate brzine vozila koja je definirana voznim ciklusom izračunava se kutna brzina kotača ω_{kotaca} a zatim se preko omjera diferencijala i_0 i stupnja prijenosa h dolazi do brzine motora ω_e :

$$\omega_e = \omega_{kotaca} \cdot i_0 \cdot h \quad (4.12)$$

Koristeći drugu upravljačku varijablu τ_e i korisnost mehaničke transmisije η_t dobiva se snaga SUI motora koja se prenosi do kotača:

$$P_{ice} = \omega_{ice} \cdot \tau_{ice} \cdot \eta_t \quad (4.13)$$

Kada od snage zahtijevane od strane vozača P_d oduzmemo snagu SUI motora dobivamo snagu koju mora dati ES-a:

$$P_{mg} = P_d - P_{ice} \quad (4.14)$$

Ovisno o tome radi li električni stroj u motorskom ili generatorskom modu, pomoću jednadžba (3.11.) i (3.12.) izračunava se snaga koja ulazi u model baterije te se dalje jednadžbom (3.13.) izračunava vrijednost promjene SoC -a ($S\dot{o}C$). Ta vrijednost se koristi za izračun vrijednosti SoC -a u $k+1$ koraku:

$$SoC(k+1) = SoC(k) + S\dot{o}C \quad (4.15)$$

Prilikom upravo opisanog postupka nije rijetkost da pokoja varijabla poprimi vrijednost koja ili fizikalno nije moguća ili odstupa od zadanog raspona vrijednosti. Iz tog razloga uvode se faktori penalizacije u fazi optimiranja. Penaliziraju slijedeće veličine ako odstupaju od definiranih vrijednosti:

$$\omega_{ice} < \omega_{ice,min}$$

$$\omega_{ice} > \omega_{ice,max}$$

$$\omega_{mg} > \omega_{mg,max}$$

$$\tau_{mg,mot} > \tau_{mg,max}$$

$$\tau_{\text{mg,gen}} < -\tau_{\text{mg,max}}$$

$$\text{SoC}(k+1) < 0$$

$$\text{SoC}(k+1) > 1$$

Također se penalizira negativna vrijednost pod korjenom jednadžbe (3.14.):

$$U_{\text{oc}}^2(\text{SoC}) - 4R(\text{SoC}, i)P_{\text{bat}} < 0$$

Posebna penalizacija odnosi se u krajnjem vremenskom diskretnom koraku ako vrijednost SoC-a ne odgovara zadanoj ciljnoj vrijednosti $\text{SoC}_{\text{target}}$. Na taj način forsira se da vrijednost SoC-a bude što bliža zadanoj vrijednosti.

5. REZULTATI OPTIMIRANJA

U ovome poglavlju dani su rezultati DP optimiranja za vozni ciklus sa i bez uključenih LEZ zona. Usporedba tih rezultata ključna je za validaciju koncepta LEZ zona jer daje rezultate potrošnje goriva u najboljim mogućim uvjetima. Na temelju dobivenih saznanja kasnije će biti razvijena realistična upravljačka strategija koja će upravljanje pogonom pokušati približiti dobivenim optimalnim vrijednostima.


5.1. Usporedba potrošnje goriva

Potrošnja goriva svakako je najzanimljiviji parametar pri validaciji koncepta LEZ jer opisuje ekonomski aspekt uvođenja LEZ zona. U slučaju bez LEZ zona, zahtijevana snaga na kotaču P_d može biti isporučena bilo kojom kombinacijom snaga SUI motora ili ES-a. Zadaća optimiranja bila je upravo ta da odredi optimalnu kombinaciju snaga koja minimizira potrošnju energije. U slučaju kada se vozilo nalazi u LEZ zoni, režim rada je striktno električan te nema toliko prostora za kalkuliranje rješenja. Snaga zahtijevana na kotaču ujedno je i snaga koju mora isporučiti ES a optimirati se može jedino stupanj prijenosa h . To u konačnici ima i svoju cijenu koja se očituje u povećanoj potrošnji goriva.


iznos početnog/krajnjeg Soc-a	potrošnja goriva bez LEZ zona [L]	potrošnja goriva sa LEZ zonama [L]
0.3	2.077	2.308 (+11.1%)
0.5	2.043	2.146 (+5.0%)
0.8	1.966	2.183 (+11.0%)

Tablica 7: Optimalna potrošnja goriva za vozne cikluse


Vidljivo je kako rezultat za stanje SoC -a od 0.5 mnogo povoljniji a jedan od razloga sigurno je to što je otpor punjenja baterije niži na srednjim vrijednostima SoC -a kao se vidi na slici 15. Ako bi se radilo o HEV (eng. skrać. Hybrid Electric Vehicle) autobusu, logično bi bilo da se stanje SoC -a održava oko sredine gdje je najpovoljnija razlika u potrošnji no kod PHEV vozila vjerojatnije je da će se baterija puniti do kraja pa će stoga i razlika u potrošnji varirati od 5 do 11%. Svi dalje prikazani grafovi odnosit će se na slučaj gdje je početno i krajnje stanje SoC -a 0.5.



Slika 16: Grafička usporedba kretanja stanja SoC-a sa i bez uključenih LEZ zona



Slika 17: Optimalne radne točke SUI motora za slučaj sa i bez uključenim LEZ zonama



Slika 18: Optimalne radne točke ES-a za slučaj sa i bez uključenim LEZ zonama

Ako slike 17 i 18 usporedimo sa slikama 12 i 13 koje prikazuju mapu potrošnje goriva te mapu korisnosti električnog stroja možemo uočiti da vrijednosti više odskakuju od optimalnih kada su LEZ zone uključene. To je posebice vidljivo na mapi za ES jer se jedino on koristi u LEZ zonama. Otklon od optimalnih radnih točaka rezultira smanjenu efikasnost punjenja i pražnjenja baterije a to u konačnici dovodi do porasta potrošnje goriva.

6. RAZVOJ UPRAVLJAČKE STRATEGIJE

U ovome poglavlju bit će razrađena realistična upravljačka strategija koja upravlja pogonom autobusa ovisno trenutnom zahtjevu vozača. Dobiveni rezultati bit će uspoređivani s rezultatima dobivenim DP optimiranjem kako bi se utvrdilo koliko je odstupanje realistične strategije od optimalne te koliko još ima prostora za poboljšanje.

6.1. Koncept upravljačke strategije s primjenom na LEZ zone

Upravljačka strategija za vožnju S LEZ zonama ne razlikuje se mnogo od upravljačke strategije slikom (11) i opisane u poglavlju 3.2. Glavna razlika je jasno to da je mod rada u LEZ zoni isključivo električan što znači da svu zahtijevanu snagu mora namiriti ES:

$$P_{\text{mg}} = P_{\text{d}} \quad (6.1)$$

Za razliku od DP optimiranja gdje se tražilo globalno optimalno rješenje upravljačkih varijabli za unaprijed poznat ciklus nagiba i brzina, upravljačka strategija mora odlučivati o pogonu ovisno u trenutnim uvjetima. Sustav ne može predvidjeti kakav će biti vozačev zahtjev za brzinom vozila ali uz pomoć GPS-a može se predvidjeti koliko je vozilo udaljeno od sljedeće LEZ zone. Zbog toga se uvodi pojas pripreme u duljini od 1km prije ulaska u LEZ zonu za vrijeme kojeg se stanje SoC-a prilagođava na skorašnju vožnju kroz LEZ zonu. GPS također može dati podatke o nadmorskoj visini rute kojom autobus vozi te se može izračunati razlika u visinama prilikom ulaska i izlaska iz LEZ zone. Taj podatak je koristan jer pomoću njega možemo procijeniti koliko razliku potencijalne energije treba savladati ES pri prolasku kroz LEZ zonu.

$$E_p = m_v \cdot g \cdot \Delta h \quad (6.2)$$

Ideja je da se ta energija dovede bateriji prije ulaska u LEZ zonu kako bi stanje SoC-a po izlasku iz LEZ zone bilo približno referenci. Analizom voznih ciklusa utvrđeno je da autobus prosječno vozi brzinom od 21.8km/h što znači da put od jednog kilometra u prosjeku prevari u 165s. Ako podijelimo dobivenu potencijalnu energiju sa tim vremenom dolazimo do okvirne procjene snage kojom se baterija treba puniti kada se vozilo nađe 1 kilometar pred LEZ zonom.

$$P_p = E_p / 165 \quad (6.3)$$

Ovo su dakako prilično grube procjene jer točno vrijeme do ulaska u zonu ovisi o brzini vozila ali jasno daju do znanja treba li bateriju puniti ili prazniti prije ulaska u LEZ zonu. Dobivena snaga dodaje se snazi SUI motora slično kao i P_{bat} .

$$P_{ICE} = P_d + P_{bat} + P_p \quad (6.4)$$

U slučaju kada se vozilo nalazi u pojasu ispred LEZ zone prag uključivanja SUI motora P_{prag} postavlja se na nižu vrijednost jer je potrebno da motor radi kako bi pripremao stanje *SoC*-a. Još jedna razlika je ta da se uvodi promjenjivi faktor pojačanja u regulatoru baterije čiji iznos raste linearno s prijeđenim putem i računa se prema jednadžbi:


$$K = 1 \cdot 10^5 \frac{dist(t)}{dist_{max}} \quad (6.5)$$

6.2. Rezultati realistične upravljačke strategije

Prije nego se iznesu vezani uz parametre pogona, valja provjeriti točnost postavljenog modela. Osnovni uvjet koji mora biti zadovoljen je da zahtijevana snaga na kotaču bude u potpunosti isporučena od strane SUI motora i ES-a.

$$P_d = P_{ice} + P_{mg} \quad (6.6)$$

Treba napomenuti da ova činjenica sama po sebi nikako ne garantira da je model točan ali pokazuje da je osnovni uvjet ispunjen. Detaljna kontrola točnosti provedena je brojnim drugim testiranjima.



Slika 19: Usporedba zahtijevane P_d i isporučene snage $P_{ice} + P_{mg}$

Na slici 18 vidljivo je da se zahtijevana i isporučena snaga dobro poklapaju osim na samom kraju voznog ciklusa. Kao i kod DP optimiranja zahtijeva se da početni i krajnji *SoC* budu


jednaki. Pred kraj voznog ciklusa vozilo se nalazi na padini što se vidi po negativnoj vrijednosti P_d a stanje SoC -a nalazi se iznad vrijednosti SoC_{target} . U tom slučaju jedini način da se osigura točnost SoC -a je da se energija iza baterije potroši na mehaničkim kočnicama. To znači da će dobiveni rezultati potrošnje goriva biti nešto veći nego je to potrebno, samo iz razloga da se postigne točnost krajnjeg rezultata. Povećanje potrošnje u visini od 12-13% govori da se postojeća upravljačka strategija još dosta da popraviti.

iznos početnog/krajnjeg SoC -a	potrošnja goriva dobivena optimiranjem [L]	potrošnja goriva dobivena upravljačkom strategijom [L]
0.3	2.308	2.623 (+13.6%)
0.5	2.146	2.437 (+13.6%)
0.8	2.183	2.448 (+12.1%)

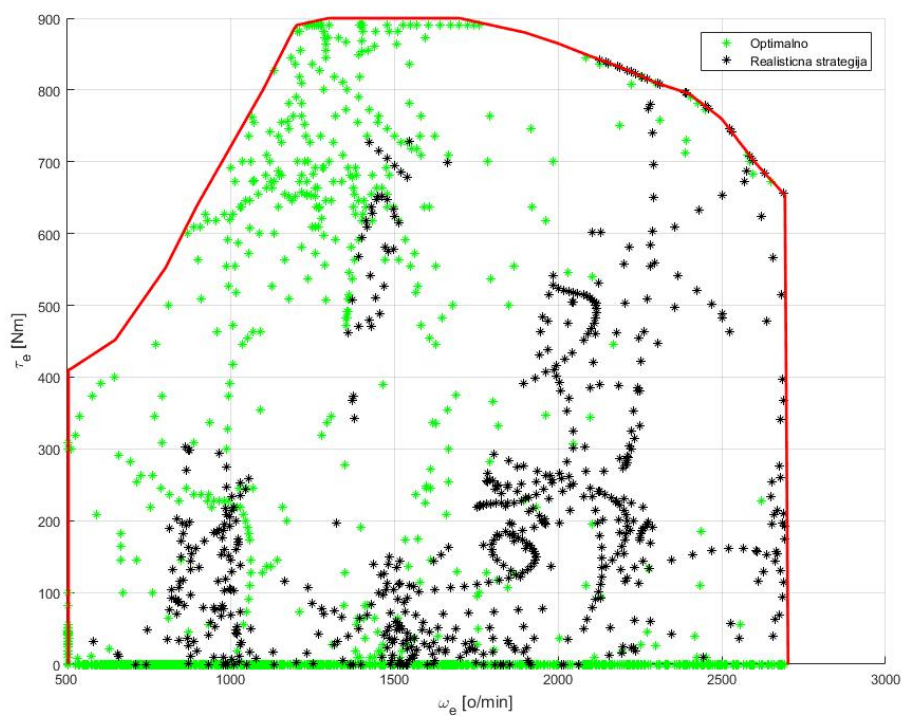
Tablica 8: Usporedba potrošnje goriva za uključene LEZ zone

Iako se zahtijeva da je vožnja kroz LEZ zone isključivo električna, u specijalnom slučaju kada snaga ES-a ne može zadovoljiti zahtijevanu snagu P_d , uključuje se SUI motor i nadoknađuje manjak snage. Moment ES-a τ_{mg} tada se postavlja na maksimalni mogući a snaga SUI motora računa se prema jednadžbi (6.7). Takav slučaj pojavljuje se dvaput kako je prikazano slikom 22.

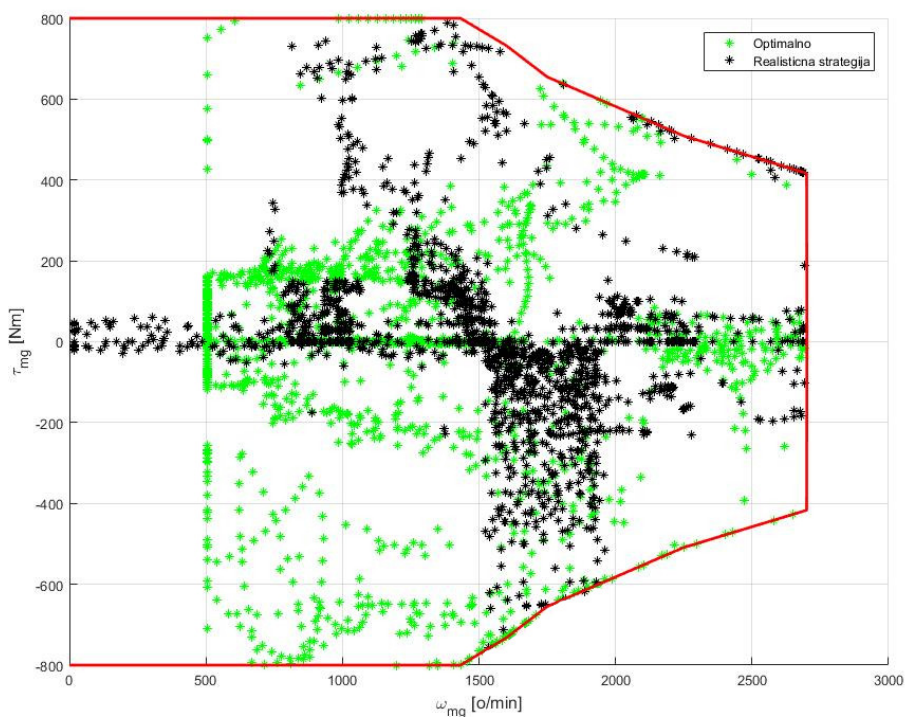
$$P_{ice} = P_d - P_{mg} \quad (6.7)$$



Slika 20: Moment SUI motora



Slika 21: Radne točke SUI motora za uključene LEZ zone dobivene DP optimiranjem i realističnom strategijom



Slika 22: Radne točke ES-a za uključene LEZ zone dobivene DP optimiranjem i realističnom strategijom

7. ZAKLJUČAK

Zadatak ovog rada bio je da ustvrdi aspekte korisnosti uvođenja LEZ zona (engl. skrać. LEZ, Low Emission Zones) na primjeru javnog gradskog prijevoza u Dubrovniku. LEZ zone predefinirana su područja u kojima vrijede posebna pravila vezana za emisiju štetnih plinova a svrha im je da smanje zagađenje, buku i gužvu u urbanim područjima. U sklopu zadatka, odabrane su potencijalne LEZ zone na kojima će se vršiti ispitivanje. Postavljen je i opisan kvazistacionaran model temeljen na PHEV (engl. skrać. PHEV, Plug-in Hybrid Electric Vehicle) autobusu marke Volvo 7900 koji se ponaša kao paralelni hibrid. Kao ulaz u model autobusa poslužili su realni vozni ciklusi snimljeni na ruti Babin Kuk – Pile [xy].

Nadalje je provedeno optimiranje upravljačkih varijabli momenta SUI motora τ_{ice} stupnja prijenosa h za slučaj uključenih i isključenih LEZ zona. Za algoritam optimiranja odabran je algoritam dinamičkog programiranja (DP) koji traži globalno optimalno rješenje. Logično je da će uvođenje LEZ zona povećati ukupnu potrošnju goriva a rezultati dobiveni optimiranjem pokazuju da se radi o povećanju od 5 do 11%. Uzimanjem optimalne referentne vrijednosti stanja napunjenosti baterije povećanje potrošnje može se zadržati na niskih 5%. S ekonomske strane gledišta to automatski znači da cijena vožnje raste za otprilike isti iznos.

Na temelju rezultata dobivenih optimiranjem razvijena je realistična upravljačka strategija koja kvalitetu upravljanja vozilom nastoji približiti optimalnom rješenju. Za razliku od DP algoritma kojem su unaprijed poznati profili brzina, realistična strategija upravljanja mora odrediti varijable pogona s obzirom na trenutni zahtjev vozača, bez saznanja o tome što slijedi. Stoga ne čudi da su rezultati potrošnje goriva dobiveni upravljačkom strategijom viši za 12 do 13%. Uz pomoć GPS tehnologije autobus može predvidjeti kada će ući u LEZ zonu te kakvi ga nagibi očekuju na ruti. U razvijenoj upravljačkoj strategiji ti su podaci uzeti u obzir ali na prilično niskoj razini. Naprednija upotreba GPS tehnologije i detaljnija analiza tih podataka sigurno bi dovela do bolje upravljačke strategije. Teško je reći do koje mjere se realistična upravljačka strategija može približiti optimalnom rješenju no prostora za to uvijek ima.

Na kraju se može zaključiti da je u ovom slučaju uvođenja LEZ zona, kao i uvijek kada je se govori o "zelenim" tehnologijama, riječ o dvosjeklom maču – postoji jasna prednost kada je riječ o zaštiti okoliša no, sa financijske strane su troškovi veći. U ovom slučaju to iznosi 5% do 11% više prema rezultatima optimiranja.

8. PRILOG

8.1. C kod realistične upravljačke strategije

```

w_kotaca = u(0);           /* ulaz u kontroler - brzina kotaca rad/s */
tau_kotaca = u(1);         /* ulaz u kontroler - moment na kotacima */
SoC = u(2);                /* stanje napunjenosti baterije SoC */
dist = u(3);               /* prijedeni put [m] */

tau_kot_abs = fabs(tau_kotaca); /* racunanje apsolutne vrijednosti
ulaznog momenta */
vv_kmh = r_ef*w_kotaca*3.6;

dist_left = max_dist-dist;
if (dist_left<1)
{
    dist_left = 1;
}

if ((dist>c_ulaz && dist<c_izlaz)
    || (dist>p1_ulaz && dist<p1_izlaz)
    || (dist>p2_ulaz && dist<p2_izlaz))
{
    zona = 1;                // vozilo u LEZ zoni
}
else
{
    zona = 0;                // vozilo izvan LEZ
zone
}

greska = SoCR-SoC;
P_prag = 30000;              // prag uključivanja
SUI motora
Pd = (w_kotaca*tau_kotaca)/eta_T; // zahtijevana snaga

if (zona == 0)
{
    if ((dist>(c_ulaz-pojas) && dist<c_ulaz)) // definiranje pojasa
ispred LEZ zona
    {
        Peks = Peks_c;
        P_prag = 10000;
    }
    if ((dist>(p1_ulaz-pojas) && dist<p1_ulaz))
    {
        Peks = Peks_p1;
        P_prag = 10000;
    }
    if ((dist>(p2_ulaz-pojas) && dist<p2_ulaz))
    {
        Peks = Peks_p2;
        P_prag = 10000;
    }
}

```



```

K = 2.5e5;
K = K + 1e5*(dist/max_dist);

P_ICE = power_ICE(greska, K, Peks, Pd);          // izračun snage ICE
motora

if(Pd>0 && P_ICE>P_prag){
    if(vv_kmh>2.364){
        mod = 1;
        ht = optim_ht_calc_ICE(S, w_kotaca, tau_kotaca, P_ICE);
// odabir stupnja prijenosa
        we = w_kotaca*ht*io;
        wmg = we;

        te = P_ICE/we;
        te_limit = ICE_Limit_ht(S, we);
        if(te>te_limit){
            te = te_limit;
            P_ICE = we*te;
        }

        P_MG = Pd - P_ICE;
        tmg = P_MG/wmg;

        tmg_limit = MG_Limit_ht(S, wmg);
        if(tmg>tmg_limit){
            tmg = tmg_limit;
            P_MG = wmg*tmg;
        }
    }

else{
    mod = 2;
    P_MG = Pd;
    ht = optim_ht_calc_MG(S, w_kotaca, tau_kotaca, P_MG);
    wmg = w_kotaca*ht*io;
    we = 0;

    tmg = P_MG/wmg;
    tmg_limit = MG_Limit_ht(S, wmg);
    if(tmg>tmg_limit){
        tmg = tmg_limit;
        P_MG = wmg*tmg;
    }

    te = 0;
    P_ICE = 0;
}

else{
    mod = 3;
    P_MG = Pd - P_ICE;
    ht = optim_ht_calc_MG(S, w_kotaca, tau_kotaca, P_MG);
    wmg = w_kotaca*ht*io;
    we = 0;
    te = 0;
}

```

```

    tmg = P_MG/wmg;
    tmg_limit = MG_Limit_ht(S, wmg);

    if(P_MG<Pd && wmg>52){
        we = wmg;
        te = P_ICE/we;
    }

    if(greska<0 && dist_left<100){           // ovim se pred kraj
postize krajnja tocnost SoCa
        tmg = -1e5*greska;
        P_dis = we*tmg;
        P_MG = 0;
        P_ICE = 0;
        te = 0;
    }
}
else{                                       // vozilo je u LEZ zoni
    mod = 0;
    P_MG = Pd;
    P_ICE = 0;
    te = 0;

    ht = optim_ht_calc_MG(S, w_kotaca, tau_kotaca, P_MG);
    wmg = w_kotaca*ht*io;
    we = 0;

    tmg = P_MG/wmg;
    tmg = MG_Limit(S, wmg, tmg);
    P_MG = tmg*wmg;
    if(P_MG<Pd){
        P_ICE = Pd - P_MG;
        we = wmg;
        te = P_ICE/we;
    }
}

if(SoC>gp && Pd<0){
    tmg = (SoC-gp)*1e5;}
    tmg = MG_Limit(S, wmg, tmg);
if(SoC<dp && Pd>0){
    tmg = (SoC-dp)*1e5;
    P_ICE = Pd - (tmg*wmg);
    te = P_ICE/we;}

/* izlazi iz kontrolera*/
y[0] = we;
y[1] = te;
y[2] = tmg;
y[3] = wmg;
y[4] = ht;
y[5] = P_ICE;
y[6] = P_MG;
y[7] = zona;
y[8] = mod;
y[9] = Pbat;
y[10] = Peks;
}

```

LITERATURA

- [1] A. Phillips , J. Kristinsson, R. McGee, H. Yu, F. Syed, F. Tseng, D. Filev: **GreenZone Driving for Plug In Hybrid Electric Vehicles**
- [2] <http://www.libertasdubrovnik.hr/en/>
- [3] Škugor B.; Hrgetić M.; Deur J.: GPS measurement – based road grade reconstruction with application to electric vehicle simulation and analysis. In: 10th Conference on Sustainable Development of Energy, Water and Environment Systems, Dubrovnik, Croatia, 2015.
- [4] https://en.wikipedia.org/wiki/Low-emission_zone
- [5] <http://urbanaccessregulations.eu/userhome/map>
- [6] Koščak H.: Optimiranje upravljačkih varijabli hibridnog električnog autobusa za slučaj značajnih promjena nagiba ceste
- [7] <http://www.hyperbus.se/download/18.52b58bdf14510b15162b4bba/1396356737766/Hyperbus-Report+on+3+buses+built-DataSheet-Volvo7900-Hybrid-Euro-5%2CAppen....pdf>
- [8] http://productinfo.vtc.volvo.se/STPIFiles/Volvo/FactSheet/AT2412D_Eng_01_1144932.pdf
- [9] <http://www.volvobuses.com/SiteCollectionDocuments/VBC/Downloads/Volvo-D5K-Hybrid-Euro6-Fact-Sheet-EN.pdf>
- [10] <http://www.remyinc.com/docs/HVH410R2.pdf>
- [11] Cipek M.: Modeliranje, analiza i optimalno upravljanje pogonima hibridnih električnih vozila; Doktorski rad; 2015

PRILOZI

I. CD-R disc